

基于事件触发机制和最小学习参数的 FAHV 指定时间收敛自适应控制

李江苗^{1,2}, 邵星灵^{2,3}, 徐悦梅³, 邓瑞祥³

(1. 中北大学仪器与电子学院, 太原, 030051; 2. 省部共建动态测试技术国家重点实验室, 太原, 030051;
3. 中北大学电气与控制工程学院, 太原, 030051)

摘要 针对当前吸气式高超声速飞行器自适应控制结果仅能实现误差渐近收敛于预设包络、神经权值在线更新存在计算爆炸、对机载资源过度占用的难题, 提出了基于事件触发机制和最小学习参数的 FAHV 指定时间收敛自适应控制方法。首先, 阐述了一种不依赖精确误差初值同时又能确保误差指定时间收敛的改进预设性能控制机制; 其次, 构建了用于 FAHV 干扰辨识的相对阈值事件触发神经网络; 最后, 设计了相对阈值事件触发控制算法, 有效降低了闭环控制器对通信资源的消耗, 在非等周期信号传输的基础上实现了良好的控制精度。仿真结果表明, 所提方法能够在低计算与传输资源消耗下对高度/速度参考信号实施指定时间跟踪。

关键词 吸气式高超声速飞行器; 改进预设性能控制; 相对阈值事件触发神经网络; 相对阈值事件触发控制

DOI 10.3969/j.issn.2097-1915.2024.02.006

中图分类号 V249.1 **文献标志码** A **文章编号** 2097-1915(2024)02-0048-14

An Adaptive Control with FAHV Being at Convergence on Specified Time Based on Event Triggering Mechanism and Minimum Learning Parameter

LI Jiangmiao^{1,2}, SHAO Xingling^{2,3}, XU Yuemei³, DENG Ruixiang³

(1. School of Instrument and Electronics, North University of China, Taiyuan 030051, China;

2. State Key Laboratory of Dynamic Measurement Technology, Taiyuan 030051, China;

3. School of Electrical and Control Engineering, North University of China, Taiyuan 030051, China)

Abstract Aimed at the problems that the results of current adaptive control for Flexible Air-breathing Hypersonic Vehicle (FAHV) are capable of only achieving asymptotic error convergence to the preset envelope, and the problems of computational explosion and excessive occupancy of airborne resources remain due to online updating of neural weights, an adaptive control method is proposed for FAHV specified time convergence based on event triggering mechanism and minimum learning parameters. Firstly, an improved preset performance control mechanism is proposed which does not depend on the exact initial error value and can ensure the convergence of the specified error time. Secondly, a relative threshold event-triggered neural network for FAHV interference identification is constructed. Finally, a control algorithm of relative

收稿日期: 2023-08-30

基金项目: 国家自然科学基金(62173312); 国家自然科学基金青年基金(61803348)

作者简介: 李江苗(1999-), 女, 山西运城人, 硕士生, 研究方向为高超声速飞行器控制。E-mail: sz202206110@st.nuc.edu.cn

通信作者: 邵星灵(1988-), 男, 江苏扬州人, 博士, 教授, 研究方向为高超声速飞行器控制。E-mail: shaoxl@nuc.edu.cn

引用格式: 李江苗, 邵星灵, 徐悦梅, 等. 基于事件触发机制和最小学习参数的 FAHV 指定时间收敛自适应控制[J]. 空军工程大学学报, 2024, 25(2): 48-61. LI Jiangmiao, SHAO Xingling, XU Yuemei, et al. An Adaptive Control with FAHV Being at Convergence on Specified Time Based on Event Triggering Mechanism and Minimum Learning Parameter[J]. Journal of Air Force Engineering University, 2024, 25(2): 48-61.

threshold event triggering is designed, which is capable of effectively reducing the consumption of communication resources of the closed-loop controller, and achieving good control accuracy on the basis of non-isoperiodic signal transmission. The simulation results show that the proposed method can track the height/speed reference signal on a specified time under conditions of low computing and transmission resource consumption.

Key words flexible air-breathing hypersonic vehicle; improved default performance control; relative threshold events trigger neural networks; relative threshold events trigger control

吸气式高超声速飞行器 (flexible air-breathing hypersonic vehicle, FAHV) 因其飞行速度快 (5Ma 以上)、机动能力强以及作战距离远等显著优势,可用于执行高空侦查与突防、远程运输与投送以及战略打击任务,已成为 21 世纪空天一体化技术飞速发展的新战略制高点。目前,对高超声速飞行器的研究分为助推式滑翔和吸气式巡航两条路线发展^[1]。其中,助推/滑翔式高超声速飞行器本身不具备发动机,而是通过控制升降舵、反作用喷气装置调整飞行器姿态,并依据设定的制导律滑翔至地面或海面目标。由于目前各国普遍基于成熟的弹道导弹技术发展助推/滑翔式高超声速飞行器,因此有部分型号已经列装部队,如俄罗斯已经实现“先锋”系列高超声速导弹^[1]。不同于助推/滑翔式高超声速飞行器,吸气式高超声速飞行器具有乘波体外形,采用机体—发动机一体化设计,相较于助推/滑翔式高超声速飞行器,具有尺寸小、机动能力强以及打击目标种类多样等显著优势^[2]。除此之外,吸气式高超声速飞行器采用的超燃冲压发动机具有无需携带氧化剂、高马赫数下工作效率高等特点。

相比于传统飞行器,吸气式高超声速飞行器本质上是一个强非线性、强耦合、快时变、强不确定性的多变量系统,有限的机载计算/通信资源、严苛的状态约束、未知的飞行环境给飞行控制提出了前所未有的挑战^[3-4]。

目前大多数 FAHV 控制均基于反步递推设计,其设计思想可以概括为:首先将 FAHV 系统动态写为严格反馈结构,接着将高超声速飞行器分为一个一阶的速度子系统和一个四阶的高度子系统,针对高度子系统采用由输出到输入的顺序设计虚拟控制律和执行机构的控制律。由于反步控制器构造需要依赖于精确的被控对象数学模型,其本身并不具备鲁棒性和抗扰能力。文献[5]基于自适应反步框架设计了面向 FAHV 的鲁棒控制策略,同时也引入了障碍 Lyapunov 函数来确保攻角状态响应约束在预先设计的行为包络内。文献[6]通过设计自适应更新律来估计不确定参数向量上界而非向量本身,减少了自适应更新律的数量并降低了控制器的计算复

杂度。文献[7]考虑了 FAHV 速度、高度以及攻角状态受限下反步自适应控制器设计问题。为进一步提高反步控制的鲁棒性,将反步法与智能控制技术相结合,吸引了越来越多学者的关注。文献[8]引入最小学习参数神经网络对 FAHV 各回路干扰进行在线辨识,并结合动态面框架,分别针对速度子系统和高度子系统设计了鲁棒控制器。文献[9]首次构建了基于离散状态信息的量化最小学习参数神经网络,在保证系统鲁棒性与跟踪性能的基础上降低了传感器至控制器回路的通信负担。文献[10]在吸气式高超声速飞行器控制器设计中首次引入了具有强化学习能力的演员-批评家神经网络,进一步提高了神经网络的辨识能力,但是在速度、高度跟踪的初始时刻却引发了强烈的抖振,将不可避免地恶化闭环控制系统的鲁棒性。

本文主要针对当前 FAHV 自适应控制结果仅能实现误差渐近收敛于预设包络、神经权值在线更新存在计算爆炸的难题,提出了基于事件触发机制和最小学习参数的 FAHV 指定时间收敛自适应控制方法详细设计过程。

1 FAHV 模型与问题描述

本文所采用的 FAHV 模型由 2008 年美国空军实验室的 Mirmirani 以及 Bolender 基于斜激波理论、计算流体力学等理论提出^[11]。之后 Parker 将气动力、力矩进行多项式拟合处理,得到最终面向控制的 FAHV 参数化模型^[12]:

$$\begin{cases} m\dot{V} = T \cos\alpha - D - mg \sin\gamma \\ \dot{h} = V \sin\gamma \\ \dot{\gamma} = \frac{L + T \sin\alpha}{mV} - \frac{g}{V} \cos\gamma \\ \dot{\alpha} = Q - \dot{\gamma} \\ I_{yy}\dot{Q} = M \\ \ddot{\eta}_i = -2\zeta_i\omega_i\dot{\eta}_i - \omega_i^2\eta_i + N_i, i=1,2,3 \end{cases} \quad (1)$$

式中:速度和高度分别定义为 V 和 h ; γ 、 α 和 Q 分别为航迹倾角、攻角和俯仰角速率; η_i 代表机身的弹

性模态; T, D, L, N_i, M 分别代表推力、阻力、升力、广义力、俯仰力矩; m 为 FAHV 模型的质量; I_{yy} 为俯仰转动惯量; g 为重力加速度常数; ζ_i, ω_i 为弹性模态常数。为方便后续的控制设计,参照文献[13],将面向控制的多项式拟合模型进一步写为严格反馈形式:

$$\begin{cases} \dot{V} = g_v \Phi + f_v + d_v \\ \dot{h} \approx V \gamma \\ \dot{\gamma} = g_\gamma \alpha + f_\gamma + d_\gamma \\ \dot{\alpha} = g_\alpha Q + f_\alpha + d_\alpha \\ \dot{Q} = g_Q \delta_e + f_Q + d_Q \\ \ddot{\eta}_i = -2\zeta_i \omega_i \dot{\eta}_i - \omega_i^2 \eta_i + N_i, i=1, 2, 3 \end{cases} \quad (2)$$

式中: Φ 表示超燃冲压发动机的燃流; g_v, f_v 表示速度子系统模型中的非线性项; d_v 表示速度子系统的匹配干扰。 $g_i, f_i, i=\gamma, \alpha, Q$ 分别表示高度子系统中航迹倾角、攻角、俯仰角速率通道的模型非线性项; $d_i, i=\gamma, \alpha, Q$ 分别表示高度子系统中航迹倾角、攻角、俯仰角速率通道中由参数摄动、外部扰动组成的不确定性。

该形式可分为 2 个子系统:速度子系统和高度子系统。其中,高度子系统中包含高度、航迹倾角、攻角、俯仰角速率通道,具体如图 2 所示。




图 1 FAHV 动力学示意图

基于上述给出的严格反馈形式的 FAHV 参数化模型,定义速度、高度、航迹倾角、攻角、俯仰角速率的参考信号分别为 $V_d, h_d, \gamma_d, \alpha_d, Q_d$, 对应状态的跟踪误差可表示为:

$$\begin{cases} e_v = V - V_d \\ e_h = h - h_d \\ e_\gamma = \gamma - \gamma_d \\ e_\alpha = \alpha - \alpha_d \\ e_Q = Q - Q_d \end{cases} \quad (3)$$

本文的控制目标描述为:

1) 通过设计燃流量 Φ 和升降舵偏角 δ_e 的控制规律,使得具有参数不确定性、外界扰动、气动耦合、系统非线性动态等干扰的 FAHV 闭环控制系统中所有误差信号最终一致有界;

2) 确保速度、高度跟踪误差分别满足预设的性能边界函数 $\chi_i(t), i=V, h$:

$$-\underline{\omega}_i \chi_i(t) < e_i(t) < \bar{\omega}_i \chi_i(t), i=V, h, \forall t \geq 0 \quad (4)$$

式中: $\bar{\omega}_i, \underline{\omega}_i \in (0, 1]$ 。

假设 1^[14]:各回路集总干扰项 $F_i = f_i + d_i, i=V, \gamma, \alpha, Q$ 有界:即 $|F_i| \leq \varepsilon_i, \varepsilon_i$ 为未知非负常数。

假设 2^[15]:若 $f(\cdot): \Omega \rightarrow R^n$ 为定义在紧集 Ω 上的一个连续函数,则根据万能逼近原理,存在理想神经权值矩阵 W ,使得式(5)成立:

$$f(\bar{x}) = W^T \phi(\bar{x}) + \varepsilon(\bar{x}) \quad (5)$$

式中: $\phi(\bar{x})$ 为激活函数; $\varepsilon(\bar{x})$ 为辨识误差,满足 $\varepsilon(\bar{x}) \leq \bar{\varepsilon}, \bar{\varepsilon}$ 为未知正常数。理想神经权值满足 $\|W\|_F \leq W^*, W^*$ 为未知正常数。

注 1:假设 2 基于 Stone-Weierstrass 理论^[16],已在智能控制领域^[17-19]得到了广泛的应用,因此该假设是一个常规且合理的假设。

引理 1^[20] $\forall \Upsilon \in R, \theta > 0$,使得下列不等式成立:

$$0 \leq |\Upsilon| - \Upsilon \tanh\left(\frac{\Upsilon}{\theta}\right) \leq 0.278 5 \theta \quad (6)$$

引理 2^[21] (Young's 不等式)对于任意向量 $x, y \in R^n$,下述 Young's 不等式成立:

$$xy \leq \frac{\psi^p}{p} |x|^p + \frac{1}{q\psi^q} |y|^q \quad (7)$$

式中: $\psi, p, q > 1$ 且 $(p-1)(q-1)=1$ 。

2 控制器设计

FAHV 纵向巡航控制一般可分解为高度控制和速度控制两个子系统。高度控制主要通过调节升降舵偏角实现高度误差的纠偏,通过反步递推设计虚拟控制量,确保高度子系统各通道的闭环稳定。速度控制主要通过实时计算燃流量,使得速度误差最终收敛于零点的邻域范围内。本文控制器主要包含改进预设性能控制(modified prescribed performance control, MPPC)、相对阈值事件触发条件(relative threshold based event-triggered condition, RTETC)以及相对阈值事件触发神经网络(relative threshold based event-triggered neural network, RTETNN)。

2.1 改进预设性能控制

根据式可得速度子系统的微分动态:

$$\dot{V} = g_v \Phi + f_v + d_v \quad (8)$$

以速度误差 e_v 为例,为实现速度回路误差指定时间意义下的收敛,不同于传统预设性能控制常用的指数型行为边界函数^[22],下面阐述一种包含新型包络和误差转化技术的 MPPC 设计思想。

定义 1 一个具有指定到达时间 T_a 的行为边

界函数 $\chi(t): R_{\geq 0} \rightarrow R_+$ 具有如下性质: ① 在 $t \in [0, T_a)$ 内, $\chi(t)$ 单调递减且恒正; ② $\forall t \geq T_a, \chi(t) \equiv \chi_\infty$, 其中 T_a 为预设的到达时间, χ_∞ 为正常数。

本文采用满足以上性质的行为边界函数:

$$\chi_i(t) = \begin{cases} \operatorname{csch}\left(\chi_{i0} + \frac{r_i t}{T_{ia} - t}\right) + \chi_{i\infty}, & 0 \leq t < T_{ia} \\ \chi_{i\infty}, & t \geq T_{ia} \end{cases}, i=V, h \quad (9)$$

式中: $\operatorname{csch}(\cdot)$ 表示双曲余割函数。 T_{ia} 为用户预先指定的收敛时间, χ_{i0} 用于调整行为边界函数的初值。 r_i 用于调整行为边界函数的收敛速度。 $\chi_{i\infty}$ 为跟踪误差的稳态上界。

下面给出行为边界函数 $\chi_i(t)$ 及其导数 $\dot{\chi}_i(t)$ 连续有界的严格分析。对式求导可得:

$$\dot{\chi}_i(t) = \begin{cases} \frac{-r_i T_{ia}}{(T_{ia} - t)^2} \operatorname{csch}\left(\chi_{i0} + \frac{r_i t}{T_{ia} - t}\right) \operatorname{coth}\left(\chi_{i0} + \frac{r_i t}{T_{ia} - t}\right), & 0 \leq t < T_{ia} \\ 0, & t \geq T_{ia} \end{cases} \quad (10)$$


式中: $\operatorname{coth}(\cdot)$ 为双曲余切函数。首先, $\dot{\chi}_i(t)$ 在定义域内 $\dot{\chi}_i(t) \leq 0$ 恒成立, 因此 $\chi_i(+\infty) < \chi_i(t) < \chi_i(0)$ 。接着, 由于 $\chi_i(0) = \operatorname{csch}(\chi_{i0}) + \chi_{i\infty}$ 以及 $\chi_i(+\infty) = \chi_{i\infty}$ 均为有界常值, 因此可证明行为边界函数 $\chi_i(t)$ 有界。

由式(10)可得:


$$\lim_{t \rightarrow T_{ia}^-} \dot{\chi}_i(t) = \lim_{t \rightarrow T_{ia}^+} \dot{\chi}_i(t) = \dot{\chi}_i(T_{ia}) = 0 \quad (11)$$

因此, 我们得知 $\chi_i(t)$ 在定义域内连续, 并进一步可得 $\dot{\chi}_i(t)$ 在闭区间 $[0, T_{ia}]$ 内有界。

注 2: MPPC 与预设性能控制 (prescribed performance control, PPC) 行为边界函数的对比示意图如图 2 所示。图中, PPC 行为边界函数的参数设置为: $\rho_0 = 180, \rho_\infty = 20$ 。MPPC 行为边界函数的参数设置为: $r_i = 0.025, \chi_{i0} = 0.006, \chi_{i\infty} = 20$ 。从图 4 可知, PPC 的行为边界函数即使到 65s 时仍未到达预先设定的最终值 20, 这是由于指数型函数的性质所决定的。然而, MPPC 的双曲余割型函数边界可在指定时间内到达指定值, 且指定时间可以在物理允许范围内由设计者任意配置。除此之外, 已有基于 PPC 控制器设计需要假设初始条件 $-\delta\rho(0) < e(0) < \rho(0)$ 成立。这意味着, 被控对象的系统初始状态需要事先精确已知, 但某些场景由于飞行初始条件的不确定性, 常常导致 FAHV 的初始状态无法精确获得, 理论上难以选择合适的包络边界确保初始条件成立。MPPC 借助双曲余割函数的性质: $\lim_{\chi_{i0} \rightarrow 0^+} \operatorname{csch}(0) = +\infty$, 可通过设置充分小的 χ_{i0} 使得行为边界函数具有无穷大的初值, 从而放宽对包络边界参数的选取, 消除了传统 PPC 控制器设计的保守性。



(a) PPC 行为边界函数



(b) MPPC 行为边界函数

图 2 PPC 和 MPPC 行为边界函数对比示意图

由于无法基于不等式直接设计控制器, 因此通过引入误差转化函数将式所描述的受约束系统转化为不受约束的等价形式:

$$e_i(t) = \chi_i(t) T_i(z_i(t), \underline{\omega}_i, \bar{\omega}_i), i=V, h \quad (12)$$

式中: $z_i(t)$ 代表转化后的跟踪误差; $T(\cdot)$ 代表误差转化函数, 有:

$$T_i(z_i(t), \underline{\omega}_i, \bar{\omega}_i) = \frac{\bar{\omega}_i \exp(z_i(t)) - \underline{\omega}_i \exp(-z_i(t))}{\exp(z_i(t)) + \exp(-z_i(t))} \quad (13)$$

对式(13)求逆可得:

$$z_i(t) = T_i^{-1}(e_i(t)/\chi_i(t)) = \frac{1}{2} \ln\left(\frac{e_i(t)/\chi_i(t) + \underline{\omega}_i}{\bar{\omega}_i - e_i(t)/\chi_i(t)}\right) \quad (14)$$

对式(14)求导可得:

$$\begin{cases} \dot{z}_i(t) = \zeta_i(t) (\dot{e}_i(t) - \dot{\chi}_i(t) e_i(t) / \chi_i(t)) \\ \zeta_i(t) = \left(\frac{1/(e_i(t)/\chi_i(t) + \underline{\omega}_i)}{-1/(e_i(t)/\chi_i(t) - \bar{\omega}_i)} \right) / 2\chi_i(t) \end{cases} \quad (15)$$

引理 3 如果被控对象满足初始条件 $-\underline{\omega}_i \chi_i(0) < e_i(0) < \bar{\omega}_i \chi_i(0), i=V, h$, 并且存在正常数 z_M 使得转化后的跟踪误差满足 $|z_i(t)| \leq z_M, \forall t > 0$, 则转化前的跟踪误差 $e_i(t)$ 不违背预设的指定时间行为边界函数, 即 $-\underline{\omega}_i \chi_i(t) < e_i(t) < \bar{\omega}_i \chi_i(t), i=V, h$ 。

2.2 速度子系统控制

将速度子系统动态代入式中, 有

$$\dot{z}_V(t) = \zeta_V(t) (g_V \Phi + F_V - \dot{V}_d - \dot{\chi}_V(t) e_V(t) / \chi_V(t)) \quad (16)$$

式中: $F_V = f_V + d_V$ 为速度子系统集总干扰。通过对神经权值范数而不是其本身元素进行更新,

应用计算效率高的最小学习参数神经网络^[29-30]对集总干扰进行在线估计:

$$F_V = \frac{1}{2} \varphi_V^* \mathbf{\Xi}_V(\bar{x}_V)^T \mathbf{\Xi}_V(\bar{x}_V) + \varepsilon_V(\bar{x}_V) \quad (17)$$

式中: φ_V^* 代表理想神经权值。 $\mathbf{\Xi}_V(\bar{x}_V) = [h_{V1}(\bar{x}_V), h_{V2}(\bar{x}_V), \dots, h_{Vn}(\bar{x}_V)]^T \in R^n$ 代表高斯基函数向量, 其中 $h_{Vj}(\bar{x}_V) = \exp[-(\bar{x}_V - c_{Vj})^T(\bar{x}_V - c_{Vj})/b_{Vj}^2]$, $j = 1, 2, \dots, n$ 代表高斯基函数, $c_{Vj} = [c_{Vj1}, c_{Vj2}]^T \in R^2$ 为感受野的中心向量, b_{Vj} 表示径向基函数基宽。 n 代表神经网络隐藏层节点数量。 $\bar{x}_V = [V, z_V]^T$ 为神经网络的输入状态。 ε_V 代表高斯基函数神经网络的辨识误差, 满足 $|\varepsilon_V| \leq \bar{\varepsilon}_V$, $\bar{\varepsilon}_V$ 为未知正常数。

为降低目前使用最为广泛的径向基函数神经网络(radius basis function neural network, RBFNN)在计算资源、通信资源过度消耗与占用^[23-24], 将神经输入数据非等周期采样, 构建如下的 RTETNN 来对速度回路的集总干扰进行在线辨识:

$$F_V = \frac{1}{2} \varphi_V^* \mathbf{\Xi}_V(\bar{x}_{Vr})^T \mathbf{\Xi}_V(\bar{x}_{Vr}) + \varepsilon_{Vr}(\bar{x}_{Vr}) \quad (18)$$

式中: 状态向量为 $\bar{x}_{Vr} = [\Psi_V, z_V]^T$, $\varepsilon_{Vr}(\bar{x}_{Vr})$ 为 RTETNN 的辨识误差。 Ψ_V 为速度 V 经采样后的状态, 由下列相对阈值事件触发机制提供:

$$\begin{cases} \Psi_V(t) = \begin{cases} V(t_k^V), & \text{if } \lambda_V(t) = 0 \\ V(t), & \text{otherwise} \end{cases} \\ e_{EV}(t) = \Psi_V(t) - V(t) \\ \lambda_V(t) = \begin{cases} 1, & |e_{EV}(t)| \geq \delta_V |V(t)| + m_V \\ 0, & \text{otherwise} \end{cases} \end{cases} \quad (19)$$

式中: $\delta_V \in (0, 1]$, m_V 为可调参数。 当条件 $\lambda_V(t)$ 满足时, $\Psi_V(t)$ 的值将更新为 $V(t)$, 否则仍保持上一时刻的值 $V(t_k^V)$ 。 $e_{EV}(t)$ 表示由于非等间隔采样导致的采样误差。 为在线估计理想神经权值 φ_V^* , 设计如下自适应更新律:

$$\dot{\varphi}_V = -\tau_V \text{Proj} \left[\hat{\varphi}_V, \frac{\mathbf{\Xi}_V(\bar{x}_{Vr})^T \mathbf{\Xi}_V(\bar{x}_{Vr})}{2} z_V \right] \quad (20)$$

式中: τ_V 为 RTETNN 的自适应增益; $\text{Proj}[\cdot]$ 表示投影算子。

注 3: 本文所设计的 RTETNN 与目前 RBFNN^[25-30]相比有如下优势: 首先, 归功于最小学习参数思想, RTETNN 仅仅对隐藏层权值向量的范数而非向量每个元素设计自适应更新律, 避免了 RBFNN 干扰辨识过程中学习参数过多导致计算负担过重的劣势; 其次, RTETNN 在测量端—控制端通信信道引入 RTETC 对神经网络输入信息进行非等间隔采样, 并利用采样后的信息对干扰进行辨识, 相较于 RBFNN, 可在保持相当估计精度的前提下有效降低辨识过程对测量端—控制端通信信道通信资源的显著浪费。 除此之外, 不同于文献[31]中所

提出的固定阈值事件触发神经网络(fixed threshold based event-triggered neural network, FTETNN), RTETNN 通过采用 RTETC 进一步降低了信号传输的频率。

然后, 基于 RTETNN 的干扰估计, 利用 RTETC, 同时为了降低对控制器—执行机构通信信道的占用, 针对速度子系统设计如下控制律:

$$\begin{cases} \nu_\Phi = -g_V^{-1}(1-\delta_\Phi) \left[\nu_\Phi \tanh\left(\frac{z_V \nu_\Phi}{\sigma_\Phi}\right) + \bar{m}_\Phi \tanh\left(\frac{z_V \bar{m}_\Phi}{\sigma_\Phi}\right) \right] \\ \nu_\Phi = \Gamma_V z_V + \hat{F}_V - \dot{V}_d - \dot{\lambda}_V(t) e_V(t) / \chi_V(t) \end{cases} \quad (21)$$

用于控制端的 RTETC 定义为

$$\begin{cases} \Phi(t) = \begin{cases} \nu_\Phi(t_k^\Phi), & \text{if } \lambda_\Phi(t) = 0 \\ \nu_\Phi(t), & \text{otherwise} \end{cases} \\ e_{E\Phi}(t) = \Phi(t) - \nu_\Phi(t) \\ \lambda_\Phi(t) = \begin{cases} 1, & |e_{E\Phi}(t)| \geq \delta_\Phi |\nu_\Phi(t)| + m_\Phi \\ 0, & \text{otherwise} \end{cases} \end{cases} \quad (22)$$

式中: Γ_V 指的是控制器增益, $e_{E\Phi}(t)$ 表示在控制器—执行器通信信道中对控制信号进行非等间隔采样造成的采样误差, $\hat{F}_V = \hat{\varphi}_V \mathbf{\Xi}_V(\bar{x}_{Vr})^T \mathbf{\Xi}_V(\bar{x}_{Vr})/2$ 表示 RTETNN 提供的集总干扰辨识结果, $\sigma_\Phi, \delta_\Phi \in (0, 1]$, m_Φ 为事件触发机制的可调参数。 其中 m_Φ 用于控制事件触发的灵敏度, 较小的 m_Φ 可以增加系统的稳定性, 减少事件的触发次数, 但可能会导致系统对变化的响应较慢, 较大的 m_Φ 可以增加系统的灵敏度和响应速度, 但可能会增加事件触发的频率和系统的抖动。 控制律中设计参数 \bar{m}_Φ 应满足 $\bar{m}_\Phi > g_V m_\Phi / (1 - \delta_\Phi)$ 来补偿采样误差对 FAHV 闭环控制系统造成的影响。

可进一步得到:

$$\begin{aligned} \nu_\Phi &= (1 + \lambda_{\Phi 1}(t) \delta_\Phi) \Phi(t) + \lambda_{\Phi 2}(t) m_\Phi \\ |\lambda_{\Phi 1}(t)| &\leq 1, |\lambda_{\Phi 2}(t)| \leq 1 \end{aligned} \quad (23)$$

接着有:

$$\Phi(t) = (\nu_\Phi(t) - \lambda_{\Phi 2}(t) m_\Phi) / (1 + \lambda_{\Phi 1}(t) \delta_\Phi) \quad (24)$$

将式代入可得:

$$\begin{aligned} \dot{z}_V(t) &\leq \zeta_V [g_V (\nu_\Phi(t) + m_\Phi) / (1 - \delta_\Phi) + \\ &F_V - \dot{V}_d - \dot{\lambda}_V(t) e_V(t) / \chi_V(t)] \end{aligned} \quad (25)$$

为便于接下来的闭环稳定性分析, 针对速度子系统, 选取正定 Lyapunov 函数 $P_1 = z_V^2 / 2 \zeta_V$, 并对其求导:

$$\begin{aligned} \dot{P}_1 &= \zeta_V^{-1} z_V \dot{z}_V \leq -z_V \nu_\Phi \tanh\left(\frac{z_V \nu_\Phi}{\sigma_\Phi}\right) - z_V \bar{m}_\Phi \tanh\left(\frac{z_V \bar{m}_\Phi}{\sigma_\Phi}\right) + \\ &z_V \nu_\Phi + z_V \bar{m}_\Phi + z_V \hat{F}_V - \Gamma_V z_V^2 \end{aligned} \quad (26)$$

式中: $\hat{F}_V = F_V - \hat{F}_V$ 表示 RTETNN 的重构误差。 应用引理 1, 式可进一步简化为:

$$\dot{P}_1 \leq -\Gamma_V z_V^2 + z_V \hat{F}_V + 0.557 \sigma_\Phi \quad (27)$$

2.3 高度子系统控制

本文将基于反步法设计面向 FAHV 高度子系统的控制律。

步骤 1 类似于速度子系统,采用 MPPC 对高度通道跟踪误差 e_h 进行误差转化,可得转化的跟踪误差 z_h 。对 z_h 求导得:

$$\dot{z}_h(t) = \zeta_h(t)((V(t)\gamma(t) - \dot{h}_d(t)) - \dot{\chi}_h(t)e_h(t)/\chi_h(t)) \quad (28)$$

然后基于 z_h 设计高度通道的虚拟控制律:

$$\bar{\gamma} = V^{-1}[-\Gamma_h z_h(t) + \dot{h}_d + \dot{\chi}_h(t)e_h(t)/\chi_h(t)] \quad (29)$$

式中: Γ_h 表示该回路的控制增益。

注 4: 在反步法递推设计过程中,常常需要求取虚拟控制量的微分信号,运用解析求导不可避免造成控制项过于繁琐冗长,并且计算复杂度会随着被控对象阶数的提高而显著增加,存在所谓的“微分爆炸”现象。为消除此类现象,简化控制器设计,引入 Sigmoid 跟踪微分器 (sigmoid tracking differentiator, STD) 来完成对虚拟控制律的高精度快速数值求导。

考虑如下微分器:

$$\begin{cases} \dot{\gamma}_d = x_1 \\ \dot{x}_1 = -a_1^2 [\text{sig}(\gamma_d - \bar{\gamma}; \mu_{0\gamma}, \mu_{1\gamma}) + \text{sig}(x_1/a_\gamma; \mu_{2\gamma}, \mu_{3\gamma})] \\ \text{sig}(\gamma_d - \bar{\gamma}; \mu_{0\gamma}, \mu_{1\gamma}) = \mu_{0\gamma} [1 + \exp(-\mu_{1\gamma}(\gamma_d - \bar{\gamma})) - 1 - 0.5], \\ \text{sig}(x_1/a_\gamma; \mu_{2\gamma}, \mu_{3\gamma}) = \mu_{2\gamma} [1 + \exp(-\mu_{3\gamma}(x_1/a_\gamma)) - 1 - 0.5] \end{cases} \quad (30)$$

式中: $\mu_{j\gamma} > 0, j = 0, 1, 2, 3$ 为设计参数。 x_1 为 $\bar{\gamma}$ 经过 STD 的微分估计, γ_d 为 STD 对 $\bar{\gamma}$ 的近似逼近。定义 $e_{s\gamma} = \gamma_d - \bar{\gamma}$ 为 STD 的估计误差。

注 5: 本节使用 STD 来获得虚拟控制律微分的原因取决于 2 个方面: ① 虽然目前动态面控制技术^[32-35]同样能够实现对虚拟控制分信号的提取,但是该策略需要控制器满足初始条件,即虚拟控制律的初始值与动态面滤波器的初始值相同。由于系统的初始状态往往无法精确测量,因此虚拟控制律的初始值无法作为控制设计的先验信息。这就导致动态面技术在工程应用中具有保守性。不同的是,STD 不需要系统的任何先验信息,使得控制算法更便于工程应用。② 相较于混合跟踪微分器^[36],STD 在实现相同信号微分能力的同时又避免了混合跟踪微分器常见的抖震现象,提高了系统的鲁棒性。将虚拟控制律代入式,将 z_h 微分动态重写为:

$$\dot{z}_h(t) = \zeta_h(t)(-\Gamma_h z_h(t) + V(t)e_{s\gamma}(t) + V(t)e_\gamma(t)) \quad (31)$$

步骤 2 航迹倾角跟踪误差的微分动态为:

$$\dot{e}_\gamma = \dot{\gamma} - \dot{\gamma}_d = g_\gamma \alpha + F_\gamma - \dot{\gamma}_d \quad (32)$$

式中: $F_\gamma = f_\gamma + d_\gamma$ 代表航迹倾角通道的非匹配集总干扰。接下来,基于最小学习参数与事件触发原理,通过设计 RTETNN 对总干扰 F_γ 进行在线辨识:

$$F_\gamma = \frac{1}{2} \varphi_\gamma^* \mathbf{\Xi}_\gamma(\bar{x}_{\gamma r})^T \mathbf{\Xi}_\gamma(\bar{x}_{\gamma r}) + \varepsilon_{\gamma r}(\bar{x}_{\gamma r})$$

$$\mathbf{\Xi}_\gamma(\bar{x}_{\gamma r}) = [\chi_{\gamma 1}(\bar{x}_{\gamma r}), h_{\gamma 2}(\bar{x}_{\gamma r}), \dots, h_{\gamma n}(\bar{x}_{\gamma r})]^T \in R^n, \quad \bar{x}_{\gamma r} = [\Psi_\gamma, e_\gamma]^T \quad (33)$$

式中: φ_γ^* 为航迹倾角通道的理想神经权值。 $\varepsilon_{\gamma r}(\cdot)$ 代表 RTETNN 的辨识误差,满足 $|\varepsilon_{\gamma r}(\cdot)| \leq \bar{\varepsilon}_{\gamma r}$, $\bar{\varepsilon}_{\gamma r}$ 为未知非负常数。 $\mathbf{\Xi}_\gamma(\bar{x}_{\gamma r})$ 为高斯基函数向量。 n 为 RTETNN 神经网络隐藏层的节点个数。 Ψ_γ 为 γ 经过非等间隔采样后的神经输入,由如下相对阈值事件触发机制得出

$$\begin{cases} \Psi_\gamma(t) = \begin{cases} \gamma(t_k^\gamma), & \text{if } \lambda_\gamma(t) = 0 \\ \gamma(t), & \text{otherwise} \end{cases} \\ e_{E\gamma}(t) = \Psi_\gamma(t) - \gamma(t) \\ \lambda_\gamma(t) = \begin{cases} 1, & |e_{E\gamma}(t)| \geq \delta_\gamma |\gamma(t)| + m_\gamma \\ 0, & \text{otherwise} \end{cases} \end{cases} \quad (34)$$

式中: $\delta_\gamma \in (0, 1]$, m_γ 为可调参数。当条件 $\lambda_\gamma(t)$ 满足时, $\Psi_\gamma(t)$ 的值将更新为 $\gamma(t)$, 否则仍保持上一时刻的值 $\gamma(t_k^\gamma)$ 。 $e_{E\gamma}(t)$ 表示由非等间隔采样导致的采样误差。为在线估计理想神经权值 φ_γ^* , 设计如下自适应更新律:

$$\dot{\hat{\varphi}}_\gamma = -\tau_\gamma \text{Proj} \left[\hat{\varphi}_\gamma, \frac{\mathbf{\Xi}_\gamma(\bar{x}_{\gamma r})^T \mathbf{\Xi}_\gamma(\bar{x}_{\gamma r})}{2} e_\gamma \right] \quad (35)$$

式中: τ_γ 为 RTETNN 的自适应增益, $\text{Proj}[\cdot]$ 表示投影算符。结合上述 RTETNN 的估计结果,构建航迹倾角通道的虚拟控制律:

$$\bar{\alpha} = g_\gamma^{-1}(-\Gamma_\gamma e_\gamma - \hat{F}_\gamma + \dot{\gamma}_d) \quad (36)$$

式中: $\hat{F}_\gamma = \hat{\varphi}_\gamma \mathbf{\Xi}_\gamma(\bar{x}_{\gamma r})^T \mathbf{\Xi}_\gamma(\bar{x}_{\gamma r})/2$ 为 RTETNN 对集总干扰 F_γ 的在线辨识。 Γ_γ 代表控制器增益。

与第 1 步类似,接下来通过设计 STD 来获取虚拟控制律 $\bar{\alpha}$ 关于时间的微分:

$$\begin{cases} \dot{\alpha}_d = x_2 \\ \dot{x}_2 = -a_\alpha^2 [\text{sig}(\alpha_d - \bar{\alpha}; \mu_{0\alpha}, \mu_{1\alpha}) + \text{sig}(x_2/a_\alpha; \mu_{2\alpha}, \mu_{3\alpha})] \\ \text{sig}(\alpha_d - \bar{\alpha}; \mu_{0\alpha}, \mu_{1\alpha}) = \mu_{0\alpha} [1 + \exp(-\mu_{1\alpha}(\alpha_d - \bar{\alpha})) - 1 - 0.5], \\ \text{sig}(x_2/a_\alpha; \mu_{2\alpha}, \mu_{3\alpha}) = \mu_{2\alpha} [1 + \exp(-\mu_{3\alpha}(x_2/a_\alpha)) - 1 - 0.5] \end{cases} \quad (37)$$

式中: $\mu_{j\alpha} > 0, j = 0, 1, 2, 3$ 为设计参数; x_2 为 $\bar{\alpha}$ 经过 STD 后的微分输出; α_d 为 STD 对 $\bar{\alpha}$ 的近似逼近; 定义 $e_{s\alpha} = \alpha_d - \bar{\alpha}$ 为 STD 的估计误差。

将虚拟控制律代入航迹倾角误差微分动态得

$$\dot{e}_\gamma = -\Gamma_\gamma e_\gamma + g_\gamma(e_{s\alpha} + e_\alpha) + \tilde{F}_\gamma \quad (38)$$

式中: $\tilde{F}_\gamma = F_\gamma - \hat{F}_\gamma$ 表示 RTETNN 的重构误差。

步骤 3 参考式, 可将攻角误差微分动态写为:

$$\dot{e}_\alpha = g_\alpha Q + f_\alpha + d_\alpha - \dot{\alpha}_d = g_\alpha Q + F_\alpha - \dot{\alpha}_d \quad (39)$$

式中: $F_\alpha = f_\alpha + d_\alpha$ 表示攻角通道的集总干扰。设计如下虚拟控制律:

$$\bar{Q} = g_\alpha^{-1}(-\Gamma_\alpha e_\alpha - \dot{F}_\alpha + \dot{\alpha}_d) \quad (40)$$

式中: Γ_α 为控制器增益。 \dot{F}_α 为 RTETNN 提供的干扰估计。

$$F_\alpha = \frac{1}{2} \varphi_\alpha^* \mathbf{E}_\alpha(\bar{x}_{ar})^T \mathbf{E}_\alpha(\bar{x}_{ar}) + \varepsilon_{ar}(\bar{x}_{ar})$$

$$\mathbf{E}_\alpha(\bar{x}_{ar}) = [h_{\alpha 1}(\bar{x}_{ar}), h_{\alpha 2}(\bar{x}_{ar}), \dots, h_{\alpha n}(\bar{x}_{ar})]^T \in R^n, \quad \bar{x}_{ar} = [\Psi_\alpha, e_\alpha]^T \quad (41)$$

式中: φ_α^* 为航迹倾角通道的理想神经权值。 $\varepsilon_{ar}(\cdot)$ 为 RTETNN 的辨识误差, 满足 $|\varepsilon_{ar}(\cdot)| \leq \bar{\varepsilon}_{ar}$, $\bar{\varepsilon}_{ar}$ 为未知非负常数。 $\mathbf{E}_\alpha(\bar{x}_{ar})$ 为高斯基函数向量。 n 为 RTETNN 神经网络隐藏层的节点个数。 \bar{x}_{ar} 为非等间隔采样后的 RTETNN 输入状态向量。 $\dot{F}_\alpha = \dot{\varphi}_\alpha \mathbf{E}_\alpha(\bar{x}_{ar})^T \mathbf{E}_\alpha(\bar{x}_{ar})/2$ 为 RTETNN 对集总干扰 F_α 的在线辨识结果。 Ψ_α 为 α 经过非等间隔采样后的输入状态, 由如下相对阈值事件触发机制得出:

$$\begin{cases} \Psi_\alpha(t) = \begin{cases} \alpha(t_k^a), & \text{if } \lambda_\alpha(t) = 0 \\ \alpha(t), & \text{otherwise} \end{cases} \\ e_{E\alpha}(t) = \Psi_\alpha(t) - \alpha(t) \\ \lambda_\alpha(t) = \begin{cases} 1, & |e_{E\alpha}(t)| \geq \delta_\alpha |\alpha(t)| + m_\alpha \\ 0, & \text{otherwise} \end{cases} \end{cases} \quad (42)$$

式中: $\delta_\alpha \in (0, 1]$, m_α 为可调参数。当条件 $\lambda_\alpha(t)$ 满足时, $\Psi_\alpha(t)$ 的值将更新为 $\alpha(t)$, 否则仍保持上一时刻的值 $\alpha(t_k^a)$ 。 $e_{E\alpha}(t)$ 表示由于非等间隔采样导致的采样误差。为在线估计理想神经权值 φ_α^* , 设计如下自适应更新律:

$$\dot{\varphi}_\alpha = -\tau_\alpha \text{Proj} \left[\dot{\varphi}_\alpha, \frac{\mathbf{E}_\alpha(\bar{x}_{ar})^T \mathbf{E}_\alpha(\bar{x}_{ar})}{2} e_\alpha \right] \quad (43)$$

式中: τ_α 为 RTETNN 的自适应增益, $\text{Proj}[\cdot]$ 表示投影算符。接下来通过设计 STD 来获取虚拟控制律 \bar{Q} 关于时间的微分:

$$\begin{cases} \dot{Q}_d = x_3 \\ \dot{x}_3 = -a_Q^2 [\text{sig}(Q_d - \bar{Q}; \mu_{1Q}, \mu_{1Q}) + \text{sig}(x_3/a_Q; \mu_{2Q}, \mu_{2Q})] \\ \text{sig}(Q_d - \bar{Q}; \mu_{1Q}, \mu_{1Q}) = \mu_{1Q} [1 + \exp(-\mu_{1Q}(Q_d - \bar{Q})) - 1 - 0.5] \\ \text{sig}(x_3/a_Q; \mu_{2Q}, \mu_{2Q}) = \mu_{2Q} [1 + \exp(-\mu_{2Q}(x_3/a_Q)) - 1 - 0.5] \end{cases} \quad (44)$$

式中: $\mu_{jQ} > 0$, $j = 0, 1, 2, 3$ 为设计参数。 x_3 为 \bar{Q} 经过 STD 后的微分输出, Q_d 为 STD 对 \bar{Q} 的近似逼近。定义 $e_{sQ} = Q_d - \bar{Q}$ 为 STD 的估计误差。

将虚拟控制律代入攻角误差微分动态得:

$$\dot{e}_\alpha = g_\alpha (e_Q + e_{sQ} + \bar{Q}) + F_\alpha - \dot{\alpha}_d =$$

$$-\Gamma_\alpha e_\alpha + g_\alpha (e_Q + e_{sQ}) + \bar{F}_\alpha \quad (45)$$

式中: $\bar{F}_\alpha = F_\alpha - \dot{F}_\alpha$ 表示 RTETNN 的重构误差。

步骤 4 对俯仰角速率跟踪误差求导可得:

$$\dot{e}_Q = \dot{Q} - \dot{Q}_d = g_Q \delta_e + F_Q - \dot{Q}_d \quad (46)$$

式中: $F_Q = f_Q + d_Q$ 代表俯仰角速率通道的集总干扰。为实现满意的轨迹跟踪效果同时降低通信资源的消耗, 设计具有采样误差补偿机制的鲁棒控制律:

$$\nu_{\delta_e} = -g_Q^{-1}(1 - \bar{h}_{\delta_e}) \cdot$$

$$\left[\nu_{\delta_e} \tanh\left(\frac{z_Q \nu_{\delta_e}}{\sigma_{\delta_e}}\right) + \bar{m}_{\delta_e} \tanh\left(\frac{z_Q \bar{m}_{\delta_e}}{\sigma_{\delta_e}}\right) \right], \quad \nu_{\delta_e} = \Gamma_Q z_Q + \dot{F}_Q - \dot{Q}_d \quad (47)$$

式中: Γ_Q 是俯仰角速率通道的控制器增益。 \bar{m}_{δ_e} 的值应满足 $\bar{m}_{\delta_e} > g_Q m_{\delta_e} / (1 - \bar{h}_{\delta_e})$, 用来实现对采样误差的补偿。同时针对该控制律设计 RTETC:

$$\begin{cases} \delta_e(t) = \nu_{\delta_e}(t_k^{\delta_e}), \quad \forall t \in [t_k^{\delta_e}, t_{k+1}^{\delta_e}) \\ e_{E\delta_e}(t) = \delta_e(t) - \nu_{\delta_e}(t) \\ t_{k+1}^{\delta_e} = \inf\{t \in R \mid |e_{E\delta_e}(t)| \geq \bar{h}_{\delta_e} |\nu_{\delta_e}(t)| + m_{\delta_e}\} \end{cases} \quad (48)$$

式中: $e_{E\delta_e}(t)$ 代表采样误差; $\sigma_{\delta_e}, \bar{h}_{\delta_e} \in (0, 1]$, m_{δ_e} 为可调参数。上式推导可得 $\nu_{\delta_e} = (1 + \lambda_{\delta 1}(t) \bar{h}_{\delta_e}) \delta_e(t) + \lambda_{\delta 2}(t) m_{\delta_e}$, 其中 $|\lambda_{\delta 1}(t)| \leq 1$, $|\lambda_{\delta 2}(t)| \leq 1$ 。进一步可得 $\delta_e(t) = (\nu_{\delta_e}(t) - \lambda_{\delta 2}(t) m_{\delta_e}) / (1 + \lambda_{\delta 1}(t) \bar{h}_{\delta_e})$ 。

$$F_Q = \frac{1}{2} \varphi_Q^* \mathbf{E}_Q(\bar{x}_Q)^T \mathbf{E}_Q(\bar{x}_Q) + \varepsilon_{Qr}(\bar{x}_Q) \mathbf{E}_Q(\bar{x}_Q) =$$

$$[h_{Q1}(\bar{x}_Q), h_{Q2}(\bar{x}_Q), \dots, h_{Qn}(\bar{x}_Q)]^T \in R^n, \quad \bar{x}_Q = [\Psi_Q, e_Q]^T \quad (49)$$

式中: φ_Q^* 代表航迹倾角通道的理想神经权值; $\varepsilon_{Qr}(\cdot)$ 代表 RTETNN 的辨识误差, 满足 $|\varepsilon_{Qr}(\cdot)| \leq \bar{\varepsilon}_{Qr}$, $\bar{\varepsilon}_{Qr}$ 为未知非负常数; $\mathbf{E}_Q(\bar{x}_Q)$ 为高斯基函数向量; n 为 RTETNN 神经网络隐藏层的节点个数; \bar{x}_Q 为非等间隔采样后的 RTETNN 输入状态向量; $\dot{F}_Q = \dot{\varphi}_Q \mathbf{E}_Q(\bar{x}_Q)^T \mathbf{E}_Q(\bar{x}_Q)/2$ 为 RTETNN 对集总干扰 F_Q 的在线辨识结果。 Ψ_Q 为 Q 经过非等间隔采样后的输入状态, 由如下相对阈值事件触发机制得出:

$$\begin{cases} \Psi_Q(t) = \begin{cases} Q(t_k^Q), & \text{if } \lambda_Q(t) = 0 \\ Q(t), & \text{otherwise} \end{cases} \\ e_{EQ}(t) = \Psi_Q(t) - Q(t) \\ \lambda_Q(t) = \begin{cases} 1, & |e_{EQ}(t)| \geq \delta_Q |Q(t)| + m_Q \\ 0, & \text{otherwise} \end{cases} \end{cases} \quad (50)$$

式中: $\delta_Q \in (0, 1]$, m_Q 为可调参数。当条件 $\lambda_Q(t)$ 满足时, $\Psi_Q(t)$ 的值将更新为 $Q(t)$, 否则仍保持上一

时刻的值 $Q(t_k^Q)$ 。 $e_{EQ}(t)$ 表示由于非等间隔采样导致的采样误差。为在线估计理想神经权值 φ_Q^* , 设计如下自适应更新律:

$$\dot{\varphi}_Q = -\tau_Q \text{Proj} \left[\varphi_Q, \frac{\mathbf{E}_Q(\bar{x}_{Qr})^T \mathbf{E}_Q(\bar{x}_{Qr})}{2} e_Q \right] \quad (51)$$

式中: τ_Q 为 RTETNN 的自适应增益, $\text{Proj}[\cdot]$ 表示投影算符。将控制律代入可得:

$$\begin{aligned} \dot{e}_Q = & -v_{\delta_e} \tanh\left(\frac{z_Q v_{\delta_e}}{\sigma_{\delta_e}}\right) - \bar{m}_{\delta_e} \tanh\left(\frac{z_Q \bar{m}_{\delta_e}}{\sigma_{\delta_e}}\right) + \\ & v_{\delta_e} + \bar{F}_Q + g_Q m_{\delta_e} / (1 - \bar{h}_{\delta_e}) - \Gamma_Q e_Q \end{aligned} \quad (52)$$

2.4 稳定性分析

定义各回路的自适应权值更新误差 $\tilde{\varphi}_V = \varphi_V - \varphi_V^*$, $\tilde{\varphi}_\gamma = \varphi_\gamma - \varphi_\gamma^*$, $\tilde{\varphi}_a = \varphi_a - \varphi_a^*$, $\tilde{\varphi}_Q = \varphi_Q - \varphi_Q^*$, 基于上述推导, 考虑如下误差系统:

$$\begin{cases} \dot{z}_V = \zeta_V \left[-v_\Phi \tanh\left(\frac{z_V v_\Phi}{\sigma_\Phi}\right) - \bar{m}_\Phi \tanh\left(\frac{z_V \bar{m}_\Phi}{\sigma_\Phi}\right) + \right. \\ \left. v_\Phi + \bar{F}_V + g_V m_\Phi / (1 - \delta_\Phi) - \Gamma_V z_V \right] \\ \dot{z}_h = \zeta_h (-\Gamma_h z_h + V e_{s\gamma} + V e_\gamma) \\ \dot{e}_\gamma = -\Gamma_\gamma e_\gamma + g_\gamma (e_{sa} + e_a) + \bar{F}_\gamma \\ \dot{e}_a = -\Gamma_a e_a + g_a (e_Q + e_{sQ}) + \bar{F}_a \\ \dot{e}_Q = -v_{\delta_e} \tanh\left(\frac{z_Q v_{\delta_e}}{\sigma_{\delta_e}}\right) - \bar{m}_{\delta_e} \tanh\left(\frac{z_Q \bar{m}_{\delta_e}}{\sigma_{\delta_e}}\right) + \\ \left. v_{\delta_e} + \bar{F}_Q + g_Q m_{\delta_e} / (1 - \bar{h}_{\delta_e}) - \Gamma_Q e_Q \right. \\ \left. \begin{aligned} \dot{\varphi}_V &= -\tau_V \text{Proj} \left[\varphi_V, \frac{\mathbf{E}_V(\bar{x}_{Vr})^T \mathbf{E}_V(\bar{x}_{Vr})}{2} z_V \right] \\ \dot{\varphi}_\gamma &= -\tau_\gamma \text{Proj} \left[\varphi_\gamma, \frac{\mathbf{E}_\gamma(\bar{x}_{\gamma r})^T \mathbf{E}_\gamma(\bar{x}_{\gamma r})}{2} e_\gamma \right] \\ \dot{\varphi}_a &= -\tau_a \text{Proj} \left[\varphi_a, \frac{\mathbf{E}_a(\bar{x}_{ar})^T \mathbf{E}_a(\bar{x}_{ar})}{2} e_a \right] \\ \dot{\varphi}_Q &= -\tau_Q \text{Proj} \left[\varphi_Q, \frac{\mathbf{E}_Q(\bar{x}_{Qr})^T \mathbf{E}_Q(\bar{x}_{Qr})}{2} e_Q \right] \end{aligned} \right\} \quad (53)$$

定理 1 考虑 FAHV 误差系统, 系统状态为 $z_V, z_h, e_\gamma, e_a, e_Q, \tilde{\varphi}_V, \tilde{\varphi}_\gamma, \tilde{\varphi}_a, \tilde{\varphi}_Q$, 对于任意有界输入 $e_{s\gamma}, e_{sa}, e_{sQ}, \bar{F}_V, \bar{F}_\gamma, \bar{F}_a, \bar{F}_Q, \tilde{\varphi}_V, \tilde{\varphi}_\gamma, \tilde{\varphi}_a, \tilde{\varphi}_Q, \sigma_\Phi, \sigma_{\delta_e}$ 可得系统输入状态稳定。另外, 若系统满足初始条件 $-\omega_i \chi_i(0) < e_i(0) < \bar{\omega}_i \chi_i(0), i = V, h$, 则 FAHV 速度、高度状态满足预设的行为边界函数 $\chi_i(t)$ 。

证明: 选择如下 Lyapunov 函数:

$$\begin{aligned} P = & \frac{1}{2\zeta_V} z_V^2 + \frac{1}{2\zeta_h \bar{V}} z_h^2 + \frac{1}{2} e_\gamma^2 + \frac{1}{2} e_a^2 + \frac{1}{2} e_Q^2 + \\ & \frac{1}{2\tau_V} \tilde{\varphi}_V^2 + \frac{1}{2\tau_\gamma} \tilde{\varphi}_\gamma^2 + \frac{1}{2\tau_a} \tilde{\varphi}_a^2 + \frac{1}{2\tau_Q} \tilde{\varphi}_Q^2 \end{aligned} \quad (54)$$

式中: \bar{V} 为未知常值满足 $\bar{V} > V > 0$ 。依据上述系统

误差动态并对式关于时间求导得

$$\begin{aligned} \dot{P} = & \zeta_V^{-1} z_V \dot{z}_V + (\zeta_h \bar{V})^{-1} z_h \dot{z}_h + e_\gamma \dot{e}_\gamma + e_a \dot{e}_a + e_Q \dot{e}_Q + \\ & \tau_V^{-1} \tilde{\varphi}_V \dot{\tilde{\varphi}}_V + \tau_\gamma^{-1} \tilde{\varphi}_\gamma \dot{\tilde{\varphi}}_\gamma + \tau_a^{-1} \tilde{\varphi}_a \dot{\tilde{\varphi}}_a + \tau_Q^{-1} \tilde{\varphi}_Q \dot{\tilde{\varphi}}_Q \end{aligned} \quad (55)$$

对式(55)进行放缩可得

$$\dot{P} \leq -\lambda_{\min}(\mathbf{\Gamma}) \|\mathbf{E}\|^2 + \|\mathbf{H}\| \|\mathbf{E}\| \quad (56)$$

式中: $\lambda_{\min}(\cdot)$ 代表矩阵的最小特征值; $\mathbf{\Gamma} = \text{diag}$

$$\left\{ \Gamma_V - \frac{1}{2}, \Gamma_h - \frac{1}{2}, \Gamma_\gamma - 1 - g_\gamma^2, \Gamma_V - 1 - \frac{g_a^2}{2}, \Gamma_Q - 1 \right\};$$

$$\mathbf{E} = [z_V, z_h, e_\gamma, e_a, e_Q, \tilde{\varphi}_V, \tilde{\varphi}_\gamma, \tilde{\varphi}_a, \tilde{\varphi}_Q]^T \text{ 且 } \mathbf{H} =$$

$$\left[e_{s\gamma}, \frac{1}{2} e_{sa}^2, g_a e_{sQ}, \bar{F}_V, \bar{F}_\gamma, \bar{F}_a, \bar{F}_Q, |\tilde{\varphi}_V| (\lambda_{\min}(\mathbf{\Gamma}) \right.$$

$$\left. + \frac{1}{8} \|\mathbf{E}_V\|^4 \right), |\tilde{\varphi}_\gamma| (\lambda_{\min}(\mathbf{\Gamma}) + \frac{1}{8} \|\mathbf{E}_\gamma\|^4),$$

$$|\tilde{\varphi}_a| (\lambda_{\min}(\mathbf{\Gamma}) + \frac{1}{8} \|\mathbf{E}_a\|^4), |\tilde{\varphi}_Q| (\lambda_{\min}(\mathbf{\Gamma}) +$$

$$\frac{1}{8} \|\mathbf{E}_Q\|^4), 0.557\sigma_\Phi, 0.557\sigma_{\delta_e}]^T。$$

式(56)可变形为:

$$\dot{P} \leq -(1 - \theta_1) \lambda_{\min}(\mathbf{\Gamma}) \|\mathbf{E}\|^2, \theta_1 \in (0, 1) \quad (57)$$

基于上述推导, 可得:

$$\begin{aligned} \|\mathbf{E}(t)\| \leq & \max\{\vartheta_1(\|\mathbf{E}(0)\|, t), \kappa_1(|e_{s\gamma}|) + \kappa_2(e_{sa}^2) + \\ & \kappa_3(|e_{sQ}|) + \kappa_4(|\bar{F}_V|) + \kappa_5(|\bar{F}_\gamma|) + \kappa_6(|\bar{F}_a|) + \\ & \kappa_7(|\bar{F}_Q|) + \kappa_8(|\tilde{\varphi}_V|) + \kappa_9(|\tilde{\varphi}_\gamma|) + \kappa_{10}(|\tilde{\varphi}_a|) + \\ & \kappa_{11}(|\tilde{\varphi}_Q|) + \kappa_{12}(|\sigma_\Phi|) + \kappa_{13}(|\sigma_{\delta_e}|)\} \end{aligned} \quad (58)$$

式中: $\vartheta_1(\cdot)$ 为 KL 函数, 其中:

$$\kappa_1(s) = \sqrt{\frac{\lambda_{\max}(\mathbf{S}_1)}{\lambda_{\min}(\mathbf{S}_1)}} \frac{s}{\theta_1 \lambda_{\min}(\mathbf{\Gamma})},$$

$$\kappa_2(s) = \sqrt{\frac{\lambda_{\max}(\mathbf{S}_1)}{\lambda_{\min}(\mathbf{S}_1)}} \frac{1}{2} s,$$

$$\kappa_3(s) = \sqrt{\frac{\lambda_{\max}(\mathbf{S}_1)}{\lambda_{\min}(\mathbf{S}_1)}} \frac{|g_a| s}{\theta_1 \lambda_{\min}(\mathbf{\Gamma})},$$

$$\kappa_4(s) = \sqrt{\frac{\lambda_{\max}(\mathbf{S}_1)}{\lambda_{\min}(\mathbf{S}_1)}} \frac{s}{\theta_1 \lambda_{\min}(\mathbf{\Gamma})},$$

$$\kappa_5(s) = \sqrt{\frac{\lambda_{\max}(\mathbf{S}_1)}{\lambda_{\min}(\mathbf{S}_1)}} \frac{s}{\theta_1 \lambda_{\min}(\mathbf{\Gamma})},$$

$$\kappa_6(s) = \sqrt{\frac{\lambda_{\max}(\mathbf{S}_1)}{\lambda_{\min}(\mathbf{S}_1)}} \frac{s}{\theta_1 \lambda_{\min}(\mathbf{\Gamma})},$$

$$\kappa_7(s) = \sqrt{\frac{\lambda_{\max}(\mathbf{S}_1)}{\lambda_{\min}(\mathbf{S}_1)}} \frac{s}{\theta_1 \lambda_{\min}(\mathbf{\Gamma})},$$

$$\kappa_8(s) = \sqrt{\frac{\lambda_{\max}(\mathbf{S}_1)}{\lambda_{\min}(\mathbf{S}_1)}} \frac{(\lambda_{\min}(\mathbf{\Gamma}) + \frac{1}{8} \|\mathbf{E}_V\|^4) s}{\theta_1 \lambda_{\min}(\mathbf{\Gamma})},$$

$$\kappa_9(s) = \sqrt{\frac{\lambda_{\max}(\mathbf{S}_1)}{\lambda_{\min}(\mathbf{S}_1)}} \frac{(\lambda_{\min}(\mathbf{\Gamma}) + \frac{1}{8} \|\mathbf{E}_\gamma\|^4) s}{\theta_1 \lambda_{\min}(\mathbf{\Gamma})},$$

$$\begin{aligned}\kappa_{10}(s) &= \sqrt{\frac{\lambda_{\max}(\mathbf{S}_1)}{\lambda_{\min}(\mathbf{S}_1)}} \frac{(\lambda_{\min}(\mathbf{\Gamma}) + \frac{1}{8} \|\mathbf{\Xi}_a\|^4)s}{\theta_1 \lambda_{\min}(\mathbf{\Gamma})}, \\ \kappa_{11}(s) &= \sqrt{\frac{\lambda_{\max}(\mathbf{S}_1)}{\lambda_{\min}(\mathbf{S}_1)}} \frac{(\lambda_{\min}(\mathbf{\Gamma}) + \frac{1}{8} \|\mathbf{\Xi}_Q\|^4)s}{\theta_1 \lambda_{\min}(\mathbf{\Gamma})}, \\ \kappa_{12}(s) &= \sqrt{\frac{\lambda_{\max}(\mathbf{S}_1)}{\lambda_{\min}(\mathbf{S}_1)}} \frac{0.557s}{\theta_1 \lambda_{\min}(\mathbf{\Gamma})}, \\ \kappa_{13}(s) &= \sqrt{\frac{\lambda_{\max}(\mathbf{S}_1)}{\lambda_{\min}(\mathbf{S}_1)}} \frac{0.557s}{\theta_1 \lambda_{\min}(\mathbf{\Gamma})}\end{aligned}\quad (59)$$

式中: $\mathbf{S}_1 = \text{diag}\{\mathbf{\Gamma}, \tau\}$, $\tau = \text{diag}\{\tau_v, \tau_\gamma, \tau_\alpha, \tau_Q\}$ 。通过在自适应更新律中使用投影算子, 可得出存在未知正常数 $\epsilon_v, \epsilon_\gamma, \epsilon_\alpha, \epsilon_Q$ 使 $\dot{\varphi}_v \leq \varphi_v^* + \epsilon_v$, $\dot{\varphi}_\gamma \leq \varphi_\gamma^* + \epsilon_\gamma$, $\dot{\varphi}_\alpha \leq \varphi_\alpha^* + \epsilon_\alpha$, $\dot{\varphi}_Q \leq \varphi_Q^* + \epsilon_Q$ 成立, 并进一步得到 $|\tilde{\varphi}_v| \leq 2\varphi_v^* + \epsilon_v$, $|\tilde{\varphi}_\gamma| \leq 2\varphi_\gamma^* + \epsilon_\gamma$, $|\tilde{\varphi}_\alpha| \leq 2\varphi_\alpha^* + \epsilon_\alpha$, $|\tilde{\varphi}_Q| \leq 2\varphi_Q^* + \epsilon_Q$ 。因此, RTETNN 的权值更新误差具有未知上界。另外, 从假设 2 可推导出神经网络辨识误差 ϵ_{ir} , $i = V, \gamma, \alpha, Q$ 具有未知上界 $\bar{\epsilon}_{ir}$, $i = V, \gamma, \alpha, Q$ 。根据高斯基函数性质, 可得 $\|\mathbf{\Xi}_i\| \leq \bar{\mathbf{\Xi}}_i$, $i = V, \gamma, \alpha, Q$ 。因此, 重构误差 $\tilde{F}_i = -\tilde{\varphi}_i \mathbf{\Xi}_i(\bar{x}_{ir})^T \mathbf{\Xi}_i(\bar{x}_{ir})/2 + \epsilon_{ir}$ (\bar{x}_{ir}) 满足 $\tilde{F}_i = -\tilde{\varphi}_i \mathbf{\Xi}_i(\bar{x}_{ir})^T \mathbf{\Xi}_i(\bar{x}_{ir})/2 + \epsilon_{ir}$ (\bar{x}_{ir}) $\leq |\tilde{\varphi}_i| \bar{\mathbf{\Xi}}_i^2/2 + \bar{\epsilon}_{ir}$ 。除此之外, 可知 STD 的估计误差 e_{si} , $i = \gamma, \alpha, Q$ 有界, 以及误差系统的输入状态 e_{sv} , e_{sa} , e_{sQ} , \tilde{F}_V , \tilde{F}_γ , \tilde{F}_α , \tilde{F}_Q , $\tilde{\varphi}_v$, $\tilde{\varphi}_\gamma$, $\tilde{\varphi}_\alpha$, $\tilde{\varphi}_Q$, σ_ϕ , σ_{δ_e} 有界。由此, 可以得出 FAHV 误差系统输入状态稳定。基于上述结论以及引理 3, 可以得到 FAHV 转化前的跟踪误差 $e_i(t)$, $i = V, h$ 满足预设的行为边界函数。定理 1 因此可以得到证明。

定理 2 对于任意的正整数 k , 存在正常数 $t_i^* > 0$, $i = \Phi, \delta_e$, 使得相邻触发间隔 $\{t_{k+1}^i - t_k^i\}$ 满足 $\{t_{k+1}^i - t_k^i\} \geq t_i^*$, $i = \Phi, \delta_e$, 则 Zeno 现象可排除。

证明: 基于速度子系统事件触发条件以及采样误差 $e_{E\Phi}(t)$ 定义, 注意到 $\lim_{t \rightarrow t_k^\Phi} e_{E\Phi}(t) = 0$, $\lim_{t \rightarrow t_{k+1}^\Phi} e_{E\Phi}(t) = \delta_\Phi |\nu_\Phi(t)| + m_\Phi > 0$ 。对 $|e_{E\Phi}(t)|$ 关于时间求导, 可得 $d|e_{E\Phi}(t)|/dt = \text{sign}(e_{E\Phi}(t)) \cdot \dot{e}_{E\Phi}(t) \leq |\dot{\nu}_\Phi(t)|$ 。基于定理 1, 容易得出依赖于有界误差变量的 $\dot{\nu}_\Phi(t)$ 存在未知上界 ξ_Φ , 可进一步得到 $\{t_{k+1}^\Phi - t_k^\Phi\} \geq t_\Phi^* \triangleq (\delta_\Phi |\nu_\Phi(t)| + m_\Phi) / \xi_\Phi > 0$, 其中 $t_{k+1}^\Phi - t_k^\Phi$ 代表速度子系统控制器—执行器通道的相邻触发间隔。因而最小触发间隔 t_Φ^* 全程严格大于 0, 彻底避免了连续频繁触发行为的发生。同理可证高度子系统最小触发间隔不小于某一非负常数 $t_{\delta_e}^*$ 。故理论上 Zeno 现象可排除。

3 仿真验证

3.1 仿真条件

为验证所设计控制策略的有效性以及相较于现有控制技术的优越性, 本文将基于 Matlab/Simulink 仿真验证平台对所提控制算法进行数值仿真。参考指令设置为加速爬升过程, 其中速度指令通过以下命令滤波器获得:

$$V(s) = \frac{82.86}{s^2 + 0.057s + 9.006 \times 10^{-4}} \quad (60)$$

高度指令通过下式低通滤波器获得:

$$h(s) = \frac{7.93}{s^2 + 0.057s + 9.006 \times 10^{-4}} \quad (61)$$

式中: s 表示 Laplace 算子。模型参数与初始系统状态可从文献[12]中得到。气动参数不确定性设置为标称值的 +30%。外部干扰设置为:

$$\begin{cases} d_{v_e} = 1 \\ d_{\gamma_e} = 0.005 \sin(0.021\pi t) \exp(-0.03t) - \\ 0.001 \sin(0.02\pi t) f_2 \\ d_{\alpha_e} = 0.01 + 0.05 \sin(0.21\pi t) \exp(-0.03t) + \\ 0.01 f_2 + 0.01 f_3 \\ d_{Q_e} = 0.01 + 2 \sin(0.02\pi t) f_1 - f_3 \end{cases} \quad (62)$$

式中:

$$\begin{aligned} f_1 &= \begin{cases} 1, t \in (50, +\infty) \\ 0, t \in [0, 50] \end{cases}; f_2 = \begin{cases} 1, t \in (70, +\infty) \\ 0, t \in [0, 70] \end{cases}; \\ f_3 &= \begin{cases} 1, t \in (80, +\infty) \\ 0, t \in [0, 80] \end{cases} \end{aligned} \quad (63)$$

控制器中所有模块参数可见表 1。


表 1 控制器参数

模块	参数
MPPC	$\bar{\omega}_v = 1, \omega_v = 0.8, \chi_{v0} = 0.006, \chi_{v\infty} = 10,$ $r_v = 0.1, T_{va} = 20, \bar{\omega}_h = 1, \omega_h = 0.8,$ $\chi_{h0} = 0.03, \chi_{h\infty} = 10, r_h = 0.01, T_{ha} = 20$
RTETNN	$\delta_v = 0.001, m_v = 0.001, \tau_v = 8\ 200, \delta_\gamma = 0.001,$ $m_\gamma = 0.001, \tau_\gamma = 1.0 \times 10^5, \delta_\alpha = 0.001,$ $m_\alpha = 0.001, \tau_\alpha = 1.46 \times 10^4, \delta_Q = 0.001,$ $m_Q = 0.001, \tau_Q = 1.0 \times 10^5, n = 40$
STD	$a_\gamma = 1000, \mu_{0\gamma} = 0.3, \mu_{1\gamma} = 0.3, \mu_{2\gamma} = 1, \mu_{3\gamma} = 1,$ $a_\alpha = 1000, \mu_{0\alpha} = 0.1, \mu_{1\alpha} = 0.1, \mu_{2\alpha} = 0.8, \mu_{3\alpha} = 0.8,$ $a_Q = 1000, \mu_{0Q} = 0.3, \mu_{1Q} = 0.3, \mu_{2Q} = 1, \mu_{3Q} = 1$
控制器	$\Gamma_v = 22.55, \Gamma_h = 2.1, \Gamma_\gamma = 2.3, \Gamma_\alpha = 2.5, \Gamma_Q = 20,$ $\sigma_\phi = 0.1, \delta_\phi = 1.0 \times 10^{-4}, \bar{m}_\phi = 1.0 \times 10^{-3},$ $m_\phi = 1.0 \times 10^{-4}, \sigma_{\delta_e} = 1.0 \times 10^{-4}, \bar{m}_{\delta_e} = 1.0 \times 10^{-3},$ $\bar{h}_{\delta_e} = 1.0 \times 10^{-4}, m_{\delta_e} = 1.0 \times 10^{-4}$


3.2 仿真结果

3.2.1 场景 1 可行性验证


算法所涉及的设计参数如表 1 所示,仿真结果如图 3~8 所示。由图 3 至 4 可以看出,在所提控制器的驱动下,FAHV 的飞行状态包括速度、高度、航迹倾角、攻角、俯仰角速率都能够快速精准地跟踪上参考信号,并且速度、高度跟踪误差收敛于指定时间行为边界函数,实现了指定时间意义下的暂稳态先验性能约束。图 5 展示了驱动 FAHV 的事件触发控制信号。可以看出,当且仅当所设计的事件触发函数超出阈值时,当前控制信号才被更新为最新采样的信息,彻底克服了时间触发框架下控制器周期性执行控制任务导致传输负担显著增加的缺陷。图 6 展示了飞行过程中的有界弹性模态。图 9 表现了 RTETNN 的估计效果以及事件触发前后的神经网络输入状态。从图 7 可以看出,所提 RTETNN 能够利用非等周期的系统状态信息进行干扰精准重构。图 8 展示了高度通道中不同预设时间 T_{ha} 条件下 MPPC 对高度跟踪误差的约束作用。




(a) 速度跟踪效果



(b) 高度跟踪效果




(c) 速度跟踪误差曲线与预设行为边界函数




(d) 高度跟踪误差曲线与预设行为边界函数


图 3 速度、高度跟踪效果。



(a) 航迹倾角跟踪效果



(b) 攻角跟踪效果



(c) 俯仰角速率跟踪效果

图 4 状态跟踪结果





图 5 控制信号








图 6 弹性模态



(a) 航迹倾角通道集总干扰估计



(b) 攻角通道集总干扰估计

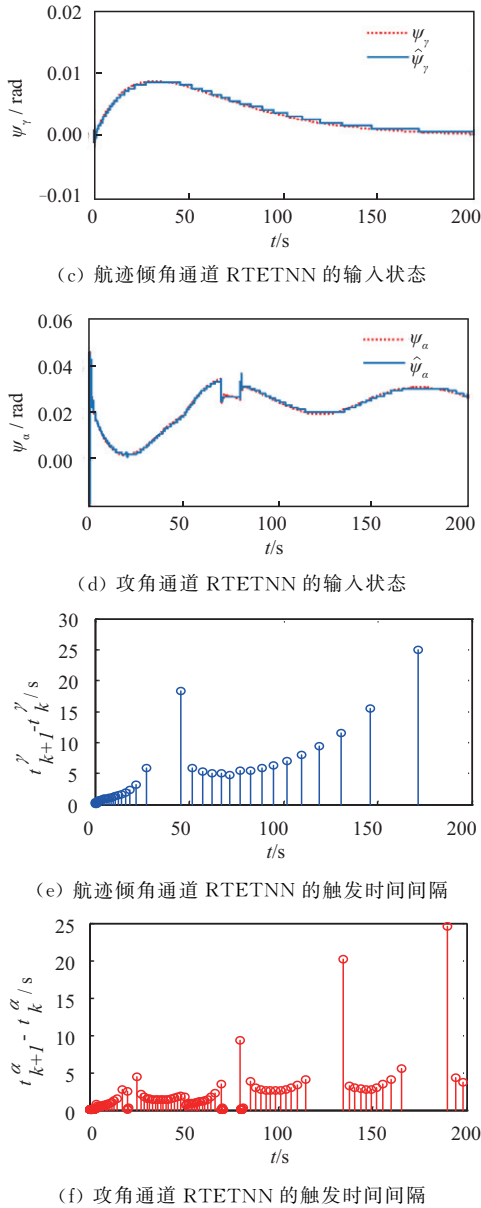


图 7 RTETNN 估计效果





图 8 不同指定时间下的高度通道跟踪误差曲线


3.2.2 场景 2 优越性验证

本文通过与目前已有 RBFNN^[37]、FTETNN^[31] 进行数值对比仿真,检验所提出的 RTETNN 在通信数据量、计算时间方面的优越性。首先,定义通信数据量为仿真中神经网络输入端时间/事件触发次数与


每次触发数据量的乘积。计算时间定义为仿真中单位采样间隔内的神经网络平均辨识时间。仿真的重构精度可通过对重构误差求标准差得到。仿真结果如图 9~10 以及表 2~3 所示。由图 9(a)~(d)可以看出,RTETNN 相较于 RBFNN、FTETNN 在触发次数与学习时间方面的优势,这是由于 RTETNN 借助事件触发函数调节神经网络输入的采样频率,利用非等周期信息进行干扰辨识。并且,RTETNN 通过对神经权值向量的范数而非向量元素进行在线更新,减少了神经网络辨识过程中学习参数的数量,并进一步降低了算法计算时间。从表 2 中的统计数据可以看出 RTETNN 相较于 RBFNN、FTETNN 在不牺牲重构精度的前提下能够有效降低通信数据量、计算时间。除此之外,图 10 以及表 3 揭示了所提控制器相较于已有连续控制策略^[38]、固定阈值事件触发控制器^[39]能够在确保相同跟踪精度的前提下有效降低通信数据量,进而减少通信资源的占用。




(a) 航迹倾角通道 RTETNN 和 FTETNN 触发次数对比



(b) 攻角通道 RTETNN 和 FTETNN 触发次数对比



(c) 航迹倾角通道 RBFNN 与 RTETNN 计算时间对比



(d) 攻角通道 RBFNN 与 RTETNN 计算时间对比





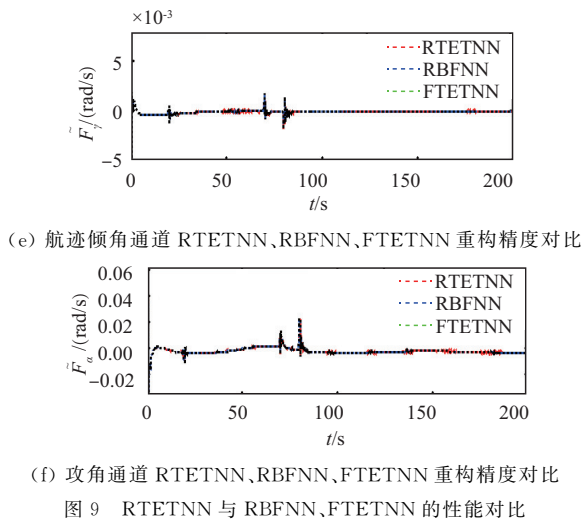


图 10 所提控制器与固定阈值事件触发控制器性能对比

表 2 RTETNN、FTETNN^[31]、RBFNN^[37] 间性能对比

性能指标	RBFNN	FTETNN	RTETNN
通信数据量 /Byte	200 000	425	39
航迹倾角通道			
计算时间 (平均值) /s	$5.555 0 \times 10^{-5}$	$5.641 1 \times 10^{-5}$	$6.627 3 \times 10^{-6}$
攻角通道			
计算时间 (平均值) /s	$5.527 1 \times 10^{-5}$	$5.613 2 \times 10^{-5}$	$4.847 7 \times 10^{-6}$
重构精度 (标准差) \tilde{F}_γ / (rad/s)	0.003 6	0.003 6	0.003 6
\tilde{F}_a / (rad/s)	0.005 7	0.005 7	0.005 7

表 3 所提控制器、固定阈值事件触发控制器^[45]、时间触发控制器^[44]性能对比

性能指标	连续时间控制器	固定阈值事件触发控制器	所提控制器
通信数据量 /Byte	Φ	27 141	14 629
δ_e	200 000	31 280	27 803
控制精度 e_V / (ft/s)	2.13	2.13	2.13
(标准差) e_Q / (rad/s)	0.03	0.03	0.03

4 结语

本文针对当前 FAHV 自适应控制结果仅能实现误差渐近收敛于预设包络、神经权值在线更新存在计算爆炸的难题,提出了基于事件触发机制和最小学习参数的 FAHV 指定时间收敛自适应控制方法详细设计过程,阐述了一种不依赖精确误差初值同时又能确保误差指定时间收敛的 MPPC,构建了用于 FAHV 干扰辨识的 RTETNN,最后设计了相对阈值事件触发控制算法,有效降低了闭环控制器对通信资源的消耗,在非等周期信号传输的基础上实现了良好的控制精度。

未来将从以下方面做进一步改进:①本文设计的相对阈值事件触发控制算法虽然能够降低对通信道带宽的占用,但仍需要传感器对触发控制算法进行持续不断的监测来判断触发条件是否得到满足。仍需要研究不需要传感器连续监测的自触发机制。②尽管本文所阐述的改进预设性能控制机制相较于传统预设性能技术在指定的时间内收敛到指定域、不需要系统初始状态精确已知、在快收敛前提下降低控制信号抖振等方面具有优势,但仍然无法实现在任意小超调意义下对跟踪误差暂稳态性能实现先验调节。

参考文献

[1] 王俊伟,冯丽,叶蕾,等. 2022 年国外高超声速领域发

- 展研究[J]. 战术导弹技术, 2023(2):15-24.
- [2] 陈扶鼎. 2022年国外高超声速武器发展回顾[J]. 中国航天, 2023(2):31-37.
- [3] RODRIGUEZ A A, DICKESON J J, CIFDALOZ O, et al. Modeling and Control of Scramjet-Powered Hypersonic Vehicles; Challenges, Trends, and Tradeoffs [C]// AIAA Guidance, Navigation and Control Conference and Exhibit (AIAA). [S.l.]:AIAA,2008:1-7.
- [4] BOLENDER M A, DOMAN D B. Nonlinear Longitudinal Dynamical Model of an Air-Breathing Hypersonic Vehicle [J]. Journal of Spacecraft & Rockets, 2012, 44(2): 374-387.
- [5] AN H, XIA H W, WANG C H. Barrier Lyapunov Function-Based Adaptive Control for Hypersonic Flight Vehicles [J]. Nonlinear Dynamics, 2017, 88(3): 1833-1853.
- [6] AN H, WU Q Q, XIA H W, et al. Fast Tracking Control of Air-Breathing Hypersonic Vehicles with Time-Varying Uncertain Parameters [J]. Nonlinear Dynamics, 2018, 91(3): 1835-1852.
- [7] LIU J X. Adaptive Control of Hypersonic Flight Vehicles with Limited Angle-of-Attack [J]. IEEE/ASME Transactions on Mechatronics, 2018, 23(2): 883-894.
- [8] ZONG Q. Robust Adaptive Dynamic Surface Control Design for a Flexible Air-Breathing Hypersonic Vehicle with Input Constraints and Uncertainty [J]. Nonlinear Dynamics, 2014, 78(1): 289-315.
- [9] SHAO X L, SHI Y. Fault-Tolerant Quantized Control for Flexible Air-Breathing Hypersonic Vehicles with Appointed-Time Tracking Performances [J]. IEEE Transactions on Aerospace and Electronic Systems, 2021, 52(7): 1261-1273.
- [10] BU X W, XIAO Y, LEI H M. An Adaptive Critic Design-Based Fuzzy Neural Controller for Hypersonic Vehicles: Predefined Behavioral Nonaffine Control [J]. IEEE/ASME Transactions on Mechatronics, 2019, 24(4): 1871-1881.
- [11] PENG Z, JIANG Y, WANG J. Event-Triggered Dynamic Surface Control of an Underactuated Autonomous Surface Vehicle for Target Enclosing [J]. IEEE Transactions on Industrial Electronics, 2021, 68(4): 3402-3412.
- [12] PARKER J T, SERRANI A, YURKOVICH S, et al. Control-Oriented Modeling of an Air-Breathing Hypersonic Vehicle [J]. Journal of Guidance Control and Dynamics, 2007, 30(3): 856-869.
- [13] BU X, WU X, ZHANG R, et al. Tracking Differentiator Design for the Robust Backstepping Control of a Flexible Air-Breathing Hypersonic Vehicle [J]. Journal of the Franklin Institute, 2015, 352(4): 1739-1765.
- [14] SUN J L, YI J Q, PU Z Q, et al. Adaptive Fuzzy Nonsmooth Backstepping Output-Feedback Control for Hypersonic Vehicles with Finite-Time Convergence [J]. IEEE Transactions on Fuzzy Systems, 2020, 28(10): 2320-2334.
- [15] PENG Z H, WANG D, WANG J. Predictor-Based Neural Dynamic Surface Control for Uncertain Nonlinear Systems in Strict-Feedback form [J]. IEEE Transactions on Neural Networks and Learning Systems, 2017, 28(9): 2156-2167.
- [16] COTTER N E. The Stone-Weierstrass Theorem and Its Application to Neural Networks [J]. IEEE Transactions on Neural Networks, 1990, 1(4): 290-295.
- [17] SHAO X L, SHI Y. Neural Adaptive Control for MEMS Gyroscope with Full-State Constraints and Quantized Input [J]. IEEE Transactions on Industrial Informatics, 2020, 16(10): 6444-6454.
- [18] HOU Z G, CHENG L, TAN M. Decentralized Robust Adaptive Control for the Multiagent System Consensus Problem Using Neural Networks [J]. IEEE Transactions on Systems Man & Cybernetics Part B, 2009, 39(3): 636-647.
- [19] CHENG L, HOU Z G, TAN M, et al. Neural-Network-Based Adaptive Leader-Following Control for Multiagent Systems with Uncertainties [J]. IEEE Transactions on Neural Networks, 2010, 21(8): 1351.
- [20] XING L, WEN C, LIU Z, et al. Robust Adaptive Output Feedback Control for Uncertain Nonlinear Systems with Quantized Input [J]. International Journal of Robust & Nonlinear Control, 2017, 27(11): 1999-2016.
- [21] 佟绍成. 非线性系统的自适应模糊控制 [M]. 北京: 科学出版社, 2006.
- [22] 杜雨欣, 王芳, 温林枝. 预设时间性能约束下高超声速飞行器的自适应容错控制 [J]. 燕山大学学报, 2024, 48(1): 62-76.
- [23] SHI Y, SHAO X L, ZHANG W D. Neural Observer-Based Quantized Output Feedback Control for MEMS Gyroscopes with Guaranteed Transient Performance [J]. Aerospace Science and Technology, 2020, 105(1): 301-310.
- [24] SHAO X L, SI H N, ZHANG W D. Event-Triggered Neural Intelligent Control for Uncertain Nonlinear Systems with Specified-Time Guaranteed Behaviors [J]. Neural Computing and Applications, 2021, 33(11): 5771-5791.
- [25] GAO T, LIU Y J, LI D, et al. Adaptive Neural Control Using Tangent Time-Varying BLFs for a Class of Uncertain Stochastic Nonlinear Systems with Full State Constraints [J]. IEEE Transactions on Cybernetics, 2021, 51(4): 1943-1953.
- [26] DAI S L, LU K, FU J. Adaptive Finite-Time Tracking Control of Nonholonomic Multirobot Formation

- Systems with Limited Field-of-View Sensors [J]. IEEE Transactions on Cybernetics, 2021(99):1-14.
- [27] DAI S, WANG C, WANG M. Dynamic Learning from Adaptive Neural Network Control of a Class of Nonaffine Nonlinear Systems[J]. IEEE Transactions on Neural Networks and Learning Systems, 2014, 25 (1): 111-123.
- [28] WANG X, TAN C P, WU F, et al. Fault-Tolerant Attitude Control for Rigid Spacecraft without Angular Velocity Measurements [J]. IEEE Transactions on Cybernetics, 2021, 51(3): 1216-1229.
- [29] QIU J, MA M, WANG T, GAO H. Gradient Descent-Based Adaptive Learning Control for Autonomous Underwater Vehicles with Unknown Uncertainties[J]. IEEE Transactions on Neural Networks and Learning Systems, 2022, 52(1):10695-10708.
- [30] YANG X, ZHENG X. Gradient Descent Algorithm-Based Adaptive NN Control Design for an Induction Motor[J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2021, 51(2): 1027-1034.
- [31] LV M G. Event-Triggered Neural Network Control of Autonomous Surface Vehicles over Wireless Network [J]. Science China Information Sciences, 2020, 63 (5): 78-79.
- [32] SHAOX L, CAO Z B, SI H N. Neurodynamic Formation Maneuvering Control with Modified Prescribed Performances for Networked Uncertain Quadrotors [J]. IEEE Systems Journal, 2021, 15 (4): 5255-5266.
- [33] KEIGHOBADI J, HOSSEINI-PISHROBAT M, FARAJI J. Adaptive Neural Dynamic Surface Control of Mechanical Systems Using Integral Terminal Sliding Mode [J]. Neurocomputing, 2020, 379: 141-151.
- [34] SHAOX L, TIAN B, YANG W. Estimator-Based MLP Neuroadaptive Dynamic Surface Containment Control with Prescribed Performance for Multiple Quadrotors[J]. Aerospace Science and Technology, 2020, 97: 105620.
- [35] SHAOX L, LIU J, CAO H L. Robust Dynamic Surface Trajectory Tracking Control for a Quadrotor UAV via Extended State Observer[J]. International Journal of Robust and Nonlinear Control, 2018, 28 (7): 2700-2719.
- [36] WANGX, CHEN Z, YUAN Z. Nonlinear Tracking-Differentiator with High Speed in Whole Course[J]. Control Theory & Applications, 2003, 20 (6): 214-222.
- [37] XI X Y. Output Feedback Fault-Tolerant Control for a Class of Nonlinear Systems via Dynamic Gain and Neural Network[J]. Neural Computing and Applications, 2020, 32(10): 5517-5530.
- [38] AN H, GUO Z, WANG G. Low-Complexity Hypersonic Flight Control with Asymmetric Angle of Attack Constraint[J]. Nonlinear Dynamics, 2020, 100: 435-449.
- [39] TABUADA P. Event-Triggered Real-Time Scheduling of Stabilizing Control Tasks[J]. IEEE Transactions on Automatic Control, 2007, 52 (9): 1680-1685.

(编辑:徐敏)